

1 LPC

je dán signál o 12-ti vzorcích $x[0] \dots x[11]$: 0, 0.707, 1, 0.707, 0, -0.707, -1, -0.707, 0, 0.707, 1, 0.707

Příklady


1. je možné vyjádřit tento signál analyticky ? Jak ?

Ano, je to sinusovka: $x[n] = \sin(2\pi fn)$ s normovanou frekvencí $f = 1/8$.

Jak se na to přišlo: že je to sinusovka asi sami vidíte. Je to periodické po $N = 8$ vzorcích a vzoreček pro normovanou frekvenci je $f = 1/N$, kde N je perioda. I kdybyste na tento vzoreček zapoměli, můžete si říci “normální sinusovka je periodická s 2π . Víme, že v tam musí být 2π a že tam musí být diskretní čas, čím bych tak ten diskretní čas vynásobil/a, aby to bylo periodické po 8-mi vzorcích ?”

Ověření Matlab:

```
n = 0:11; f = 1/8; N=12;  
x = sin (2*pi*f*n); stem(n,x);
```



2. spočítejte energii vztahenou na 1 vzorek.

součet kvadrátů absolutních hodnot vzorků (vzorky jsou reálné, takže se na absolutní hodnoty můžeme klidně vykašlat), dělíme délkou signálu:

$$E = \frac{1}{N} \sum_{n=0}^{N-1} x^2[n] = \frac{0 + 6 \times \frac{1}{2} + 3 \times 1}{12} = 0.5$$

Ověření Matlab:

```
E = 1/N * sum(x.^2)
```

Přídavná kontrola: energie sinusovky by měla být $\frac{A^2}{2}$, kde A je amplituda. Platí to ?

$$\frac{A^2}{2} = \frac{1}{2}$$

... jo, platí.

3. spočítejte průchody nulou - nejprve pohledem na ₁obrázek, pak matematicky.

pohledem na obrázek: 2

matematicky:

$$Z = \frac{1}{2} \sum_{n=1}^{N-1} |\text{sign } x[n] - \text{sign } x[n-1]|,$$

pro zjednodušení bereme znaménko čísla nula: $\text{sign } 0 = 1$. Uvědomíme si, že vedle sebe sedící vzorky se stejným znaménkem mají absolutní hodnotu rozdílu znamének 0, pokud se znaménko změní, je to 2. V našem signálu tyto přechody dostáváme dva, tedy:

$$Z = \frac{1}{2} 2 \times 2 = 2$$

4. proveďte LPC analýzu řádu 2 - musíte tedy určit koeficienty a_1 a a_2 filtru $\frac{1}{A(z)}$. Budete potřebovat autokorelační koeficienty $R[0]$, $R[1]$ a $R[2]$. Proveďte výpočet řešením standardní soustavy rovnic o dvou neznámých.

Autokorelační koeficienty se počítají pomocí:

$$R[k] = \sum_{n=0}^{N-1-k} s[n]s[n+k]$$

budeme je potřebovat pro $k=0,1,2$. Signál okopírujeme, posuneme **doleva** (ale ono je to stejně jedno...) o k , pak všechny vzorky, které budou nad sebou vynásobíme a sečteme.

$$\begin{aligned} R[0] &= \sum_{n=0}^{N-1-k} x[n]x[n] = 0^2 + 0.707^2 + \dots = 6 \\ R[1] &= \sum_{n=0}^{N-1-k} x[n]x[n+1] = 0 \times 0.707 + 0.707 \times 1 + \dots = 4.243 \\ R[2] &= \sum_{n=0}^{N-1-k} x[n]x[n+2] = 0 \times 1 + 0.707 \times 0.707 + \dots = 0.5 \end{aligned}$$

Ověření Matlab:

```
R = xcorr(x)
R = R(N:N+2)
R0 = R(1); R1=R(2); R2 = R(3);
```

LPC koeficienty jsou řešením soustavy rovnic:

$$\begin{bmatrix} R[0] & R[1] \\ R[1] & R[0] \end{bmatrix} \begin{bmatrix} a_1 \\ a_2 \end{bmatrix} = \begin{bmatrix} -R[1] \\ -R[2] \end{bmatrix}$$

tedy

$$\begin{aligned} R[0]a_1 + R[1]a_2 &= -R[1] \\ R[1]a_1 + R[0]a_2 &= -R[2] \end{aligned}$$

Na výpočet soustavy rovnic o 2 neznámých můžete jít různě, po několika neúspěšných pokusech s použitím kofaktorů jsem si to odvodil růčo: pro

$$\begin{aligned} ax + by &= c \\ dx + ey &= f \end{aligned}$$

by mělo platit:

$$x = \frac{ce - bf}{ea - bd}$$

(takže tam ty kofaktory stejně dostaneme, ha ha ha). Po dosazení:

$$a_1 = \frac{-4.243 \times 6 + 0.5 \times 4.243}{6^2 - 4.243^2} = -1.297$$

pak se to dosadí do libovolné z rovnic a vyjde:

$$a_2 = 0.843$$

Ověření Matlab:

$$A = \text{inv}(\begin{bmatrix} R_0 & R_1 \\ R_1 & R_0 \end{bmatrix}) * \begin{bmatrix} -R_1 \\ -R_2 \end{bmatrix}$$

5. Proveďte tentýž výpočet pomocí Levinsona-Durbina.

postupujeme podle rovnic 22-26 v přednášce o LPC.

$$\begin{aligned} &\text{inicializace} \\ &E^{(0)} = 6 \end{aligned}$$

$$\begin{aligned} &\text{iterace(1)} \\ &k_1 = -[R[1] + \text{nic}] / E^{(0)} = 4.243 / 6 = -0.707 \\ &a_1^{(1)} = -0.707 \\ &a_j^{(1)} \dots \text{nic} \\ &E^{(1)} = (1 - 0.707^2)6 = 3 \end{aligned}$$

$$\begin{aligned} &\text{iterace(2)} \\ &k_2 = -[R[2] + a_1^{(1)}R[1]] / E^{(1)} = \dots = 0.833 \\ &a_2^{(2)} = 0.833 \\ &a_1^{(2)} = a_1^{(1)} + k_2 a_1^{(1)} = -0.707 + 0.833 \times (-0.707) = -1.295 \end{aligned}$$

“nic” v algoritmu značí, že díky indexům není co dělat.

Ověření Matlab:

$$A = \text{levinson}(R, 2)$$

6. Vypočtete energii chyby predikce z LPC a autokorelačních koeficientů.

podle vzorečku (20) z přednášky:

$$E = R[0] + \sum_{i=1}^P a_i R[i] = 6 - 1.297 \times 4.243 + 0.834 \times 0.5 = 0.913$$

Toto je **nenormovaná energie**, pokud ji budeme chtít převést na normovanou, musíme dělit 14-ti (?? a proč ne 12-ti ??)¹.

$$E_{norm} = \frac{0.913}{14} = 0.0652$$

7. Vypočítejte signál chyby predikce - jedná se tedy o filtrování signálu $x[n]$ “inverzním” filtrem $A(z)$. Vypočtete jeho energii a srovnajte s energií vypočtenou v bodě 6.

filtrujeme filtrem $A(z) = 1 + a_1 z^{-1} + a_2 z^{-2}$, který má v časové oblasti tuto diferenční rovnici:

$$y[n] = x[n] + a_1 x[n-1] + a_2 x[n-2]$$

Musíme tedy sčítat současný vzorek s minulým násobeným a_1 a předminulým násobeným a_2 . Na to je dobré si udělat malou tabulku:

¹Odpověď: Signál má 12 vzorků, ale jelikož filtr má dvě paměti, produkuje signál ještě o dva vzorky delší (musíme počkat, až se paměti “vysypou”).

n	$x[n]$	$x[n-1]$	$a_1x[n-1]$	$x[n-2]$	$a_2x[n-2]$	$y[n]$
0	0	0	0	0	0	0
1	0.707	0	0	0	0	0.707
2	1	0.707	-0.917	0	0	0.083
3	0.707	1	-1.296	0.707	0.589	0
4	0	0.707	-0.917	1	0.833	-0.083
5	-0.707	0	0	0.707	0.589	-0.118
6	-1	-0.707	0.917	0	0	-0.083
7	-0.707	-1	1.296	-0.707	-0.589	0
8	0	-0.707	0.917	-1	-0.833	0.083
9	0.707	0	0	-0.707	-0.589	0.118
10	1	0.707	-0.917	0	0	0.083
11	0.707	1	-1.296	0.707	0.589	0
12	0	0.707	-0.917	1	0.833	-0.083
13	0	0	0	0.707	0.589	0.589

Nejprve si vyplníme sloupce $x[n]$, $x[n-1]$ a $x[n-2]$, pak k nim dopočítáme sloupce násobené koeficienty a nakonec sloupce $x[n]$, $a_1x[n-1]$ a $a_2x[n-2]$ sečteme. Zvrhlíci si to můžou spočítat i v Excelu ;-)

Spočítáme-li energii výstupního signálu:

$$E_{norm_y} = \frac{1}{14} \sum_{n=0}^{13} y^2[n]$$

zjistíme, že je to 0.065, takže vzorec pro výpočet residuální energie z LPC koeficientů a autokorelačních koeficientů nelhal.

8. Určete, kde má filtr $\frac{1}{A(z)}$ póly a jak vypadá jeho frekvenční charakteristika.

Jmenovatele filtru $H(z) = \frac{1}{A(z)}$ můžeme rozložit do pólů takto:

$$H(z) = \frac{1}{1 + a_1z^{-1} + a_2z^{-2}} = \frac{z^2}{z^2 + a_1z + a_2} = \frac{z^2}{(z - p_1)(z - p_2)}$$

Póly (tedy body, kde je jmenovatel roven nule, tedy celý výraz roven nekonečnu) jsou dány řešením rovnice:

$$z^2 + a_1z + a_2 = 0$$

Opět si vzpomeneme na středoškolskou matematiku, kde se kvadratická rovnice

$$ax^2 + bx + c = 0$$

řešila:

$$x_{1,2} = \frac{-b \pm \sqrt{b^2 - 4ac}}{2a}$$

po dosazení $a = 1$, $b = a_1 = -1.296$, $c = a_2 = 0.833$ vyjde:

$$p_1 = 0.6482 + 0.6428j, \quad p_2 = 0.6482 - 0.6428j$$

podle předpokladu vyšla dvě komplexně sdružená čísla. Pokud si tato čísla nakreslíme do komplexní roviny, začneme tušit, že filtr bude mít charakter pásmové propusti: když bude putovat bod $z = e^{j2\pi f}$ po jednotkové kružnici, přiblíží se k pólu, krátká vzdálenost k pólu "stáhne" jmenovatele $H(z)$ do malých hodnot a když je jmenovatel malý, frekvenční charakteristika bude velká². Převedeme-li póly do exponenciálního tvaru $re^{j\phi}$, dostaneme:

$$p_1 = 0.913e^{j0.781}, \quad p_2 = 0.913e^{-j0.781}$$

Zajímá nás, které frekvenci bude maximum odpovídat. Když celá kružnice (2π rad) odpovídá normované frekvenci 1, pak bude 0.781 rad odpovídat:


$$\frac{0.781}{2\pi} = 0.124 \approx \frac{1}{8}$$

To je fajn, protože filtr $\frac{1}{A(z)}$ se dobře "naučil na náš signál", který měl také frekvenci $\frac{1}{8}$.

Ověření Matlab:

²Více viz přednáška o lineární filtraci v ISS.

```
H=freqz(1,A,256); f=(0:255) / 256 * 0.5;  
plot (f,abs(H))
```



2 DTW

Jsou dány vektory s parametry³:

$$\begin{aligned} \text{testovací:} \quad & \mathbf{t} = [1 \quad 3]^T \\ \text{referenční 1:} \quad & \mathbf{r}_1 = [2 \quad 4]^T \\ \text{referenční 2:} \quad & \mathbf{r}_2 = [-1 \quad 3]^T \end{aligned}$$

Příklady

1. Určete Euklidovy vzdálenosti vektoru \mathbf{t} od \mathbf{r}_1 i od \mathbf{r}_2 a určete, který z referenčních vektorů je testovacímu blíže.

Pro výpočet Euklidovy vzdálenosti použijeme známý vzoreček pro přeponu trojúhelníka:

$$D(\mathbf{r}, \mathbf{t}) = \sqrt{(r(1) - t(1))^2 + (r(2) - t(2))^2},$$

kde $r(1), t(1)$ jsou první a $r(2), t(2)$ druhé složky jednotlivých vektorů. Takže:

$$D(\mathbf{r}_1, \mathbf{t}) = \sqrt{1^2 + 1^2} = 1.414$$

$$D(\mathbf{r}_2, \mathbf{t}) = \sqrt{(-2)^2 + 0^2} = 2$$

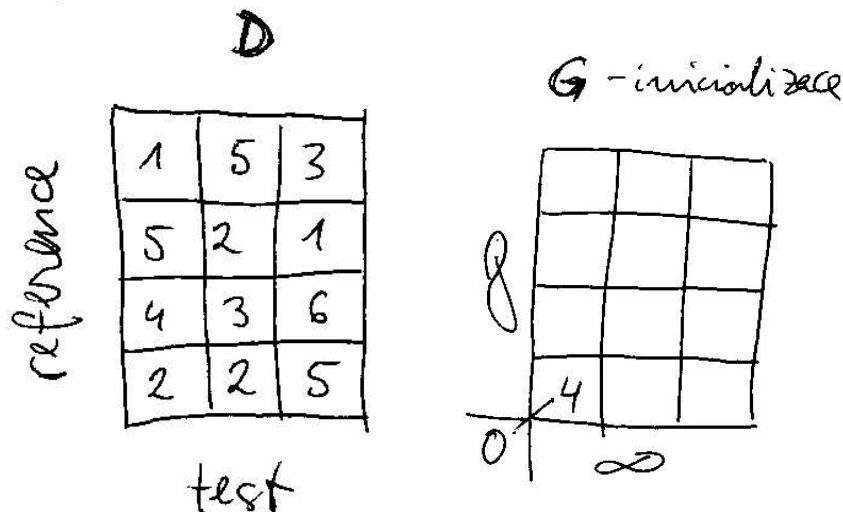
Referenční vektor \mathbf{r}_1 je testovacímu blíže.

2. Referenční posloupnost má 4 vektory, testovací má 3 vektory. Je dána "mřížka" lokálních vzdáleností (reference svisle, test vodorovně).

$$\mathbf{D} = \begin{bmatrix} 1 & 5 & 3 \\ 5 & 2 & 1 \\ 4 & 3 & 6 \\ 2 & 2 & 5 \end{bmatrix}.$$

Určete DTW vzdálenost.

Při výpočtu DTW vzdálenosti začneme tak, že si nakreslíme "mřížku" lokálních vzdáleností \mathbf{D} a inicializujeme "mřížku" částečných kumulovaných vzdáleností \mathbf{G} .




Pak budeme vyplňovat \mathbf{G} zleva doprava a zespoda nahoru tak, že v každém bodě:

$$\text{hodnota} = \min \left\{ \begin{array}{l} g \text{ souseďa vlevo} + d \\ g \text{ souseďa dole} + d \\ g \text{ souseďa vlevo dole} + 2d \end{array} \right\}$$


Z přednášek si možná pamatujete, že 2 je penalizace příliš rychlého postupu v obou směrech. Při vyplňování políčka v \mathbf{G} si zapamatujeme, odkud jsme přišli. Vyplnění prvního sloupce a prvního řádku je triviální, detail ukazuje políčko $[2, 2]$, kde se poprvé musíme skutečně rozhodnout:

³Vektory jsou sloupcové a protože se mi je nechce sloupcové sázet, je u nich všude T jako že jsou transponované ;-)

G - pokračování

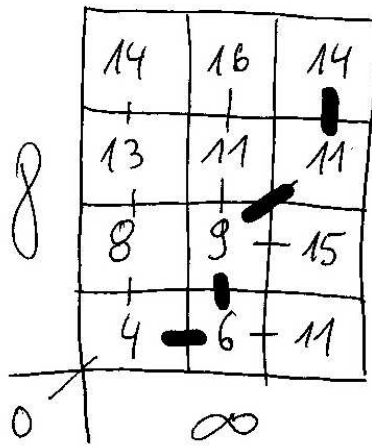


detail



Nakonec bude **G** vypadat takto:

G - hotovo



Lehce určíme DTW vzdálenost: podělíme poslední políčko součtem délek reference a testu:

$$D_{DTW} = \frac{14}{3+4} = 2$$

3. Určete optimální srovnávací cestu a průběhy "indexovacích" funkcí $r(k)$ a $t(k)$.

Optimální srovnávací cestu dostaneme zpětným trasováním z posledního políčka **G** — na obrázku je vyznačena tlustými čarami. Vidíme, že srovnávací cesta má $K = 5$ bodů, indexovací funkce budou:

pro referenci $r(k) = [1 \ 1 \ 2 \ 3 \ 4]$

pro test $t(k) = [1 \ 2 \ 2 \ 3 \ 3]$.

3 HMM

Je dán model s $N = 4$ stavy (z nichž jsou 2 vysílací). Vektory v matici \mathbf{O} mají dva prvky a je jich $T = 5$:

$$\mathbf{o}(1) = \begin{bmatrix} 0.5 \\ 1 \end{bmatrix}, \quad \mathbf{o}(2) = \begin{bmatrix} 1.2 \\ 3 \end{bmatrix}, \quad \mathbf{o}(3) = \begin{bmatrix} 1 \\ 2 \end{bmatrix}, \quad \mathbf{o}(4) = \begin{bmatrix} -0.5 \\ -3 \end{bmatrix}, \quad \mathbf{o}(5) = \begin{bmatrix} -1 \\ -5 \end{bmatrix}.$$

Model má tuto matici přechodových pravděpodobností:

$$\mathbf{A} = \begin{bmatrix} 0 & 1 & 0 & 0 \\ 0 & 0.6 & 0.4 & 0 \\ 0 & 0 & 0.7 & 0.3 \\ 0 & 0 & 0 & 0 \end{bmatrix}$$

Funkce hustoty rozdělení pravděpodobnosti v jednotlivých stavech jsou dány jedním Gaussovým rozložením s následujícími vektory středních hodnot a směrodatných odchylek:

$$\mu_2 = \begin{bmatrix} 1 \\ 2 \end{bmatrix}, \quad \sigma_2 = \begin{bmatrix} 2 \\ 2 \end{bmatrix}$$


$$\mu_3 = \begin{bmatrix} -1 \\ -2 \end{bmatrix}, \quad \sigma_3 = \begin{bmatrix} 2 \\ 2 \end{bmatrix}$$

Příklady

Matlabové ověření k těmto příkladům najdete v souboru `cviko2_hmm_reseni.m`

1. určete všechny možné stavové sekvence \mathbf{X} .

Bude dobré si tento HMM nejprve nakreslit:



Všechny stavové sekvence musí začínat prvním nevysílacím stavem — č. 1 — a končit posledním nevysílacím — č. 4. Dva vysílací stavy si musí rozdělit všechny vektory, celková délka všech sekvencí tedy bude 7. Všechny možné sekvence jsou 4:

$$X_1 = [1 \ 2 \ 3 \ 3 \ 3 \ 3 \ 4]$$

$$X_2 = [1 \ 2 \ 2 \ 3 \ 3 \ 3 \ 4]$$

$$X_3 = [1 \ 2 \ 2 \ 2 \ 3 \ 3 \ 4]$$

$$X_4 = [1 \ 2 \ 2 \ 2 \ 2 \ 3 \ 4]$$

Jiné sekvence nejsou platné, protože v modelu se nedají přeskokovat stavy.

2. pro každou z nich určete pravděpodobnost vyslání: $P(O, X|M)$. V tomto úkolu budete potřebovat výpočet vysílacích pravděpodobností Pro $b_2(\mathbf{o}(1))$ spočítejte sami, pro ostatní jsou zde:

	$\mathbf{o}(1)$	$\mathbf{o}(2)$	$\mathbf{o}(3)$	$\mathbf{o}(4)$	$\mathbf{o}(5)$
b_2	??????	0.0349	0.0398	0.0013	0.0001
b_3	0.0098	0.0010	0.0033	0.0340	0.0129

Nejprve musíme spočítat vysílací pravděpodobnost $b_2(\mathbf{o}(1))$ – dostaneme ji tak, že dosadíme $\mathbf{o}(1)$ do funkce hustoty rozložení pravděpodobnosti druhého stavu. Jelikož jsou tato rozložení dána pouze pomocí středních hodnot a směrodatných odchylek, nemusíme se naštěstí starat o inverzi kovarianční matice a její determinant, ale použijeme zjednodušený vzorec (rovnice 5 v přednášce o HMM), kdy dostaneme vysílací pravděpodobnost jako **součin** hodnot dvou jednorozměrných Gaussovek.

$$b_2(\mathbf{o}(1)) = \frac{1}{\sqrt{2\pi} \sigma_{21}} e^{-\frac{(\mathbf{o}(1)_1 - \mu_{21})^2}{2\sigma_{21}^2}} \times \frac{1}{\sqrt{2\pi} \sigma_{22}} e^{-\frac{(\mathbf{o}(1)_2 - \mu_{22})^2}{2\sigma_{22}^2}} = \dots = 0.034$$

Tabulku tedy můžeme doplnit.

Při výpočtu pravděpodobností $P(O, X|M)$ po jednotlivých cestách se řídíme pravidlem “násobit všechny pravděpodobnosti, které po cestě potkáme”, tedy všechny přechodové a vysílací vždy bereme podle toho, který stav “vysílá” který vektor. Bude to brutální, ale tady jsou celkové vzorečky:

$$P(O, X_1|M) = a_{12} b_2(\mathbf{o}(1)) a_{23} b_3(\mathbf{o}(2)) a_{33} b_3(\mathbf{o}(3)) a_{33} b_3(\mathbf{o}(4)) a_{33} b_3(\mathbf{o}(5)) a_{34} = 2.02 \times 10^{-12}$$

$$P(O, X_2|M) = a_{12} b_2(\mathbf{o}(1)) a_{22} b_2(\mathbf{o}(2)) a_{23} b_3(\mathbf{o}(3)) a_{33} b_3(\mathbf{o}(4)) a_{33} b_3(\mathbf{o}(5)) a_{34} = 6.12 \times 10^{-11}$$

$$P(O, X_3|M) = a_{12} b_2(\mathbf{o}(1)) a_{22} b_2(\mathbf{o}(2)) a_{22} b_2(\mathbf{o}(3)) a_{23} b_3(\mathbf{o}(4)) a_{33} b_3(\mathbf{o}(5)) a_{34} = 6.36 \times 10^{-10}$$

$$P(O, X_4|M) = a_{12} b_2(\mathbf{o}(1)) a_{22} b_2(\mathbf{o}(2)) a_{22} b_2(\mathbf{o}(3)) a_{22} b_2(\mathbf{o}(4)) a_{23} b_3(\mathbf{o}(5)) a_{34} = 1.6 \times 10^{-11}$$

3. určete Baum-Welchovu pravděpodobnost: $P(O|M) = \sum_{\forall X} P(O, X|M)$

Tato pravděpodobnost je sumou přes všechny cesty:

$$P(O|M) = 7.12 \times 10^{-10}$$

4. určete Viterbiho pravděpodobnost: $P^*(O|M) = \max_{\forall X} P(O, X|M)$

Tato pravděpodobnost je maximem přes všechny cesty:

$$P(O|M) = 6.36 \times 10^{-10}$$

5. určete log-Viterbiho pravděpodobnost: $\log P^*(O|M)$ pomocí algoritmu token-passing. Odlogaritmujte a srovnejte s bodem 4.

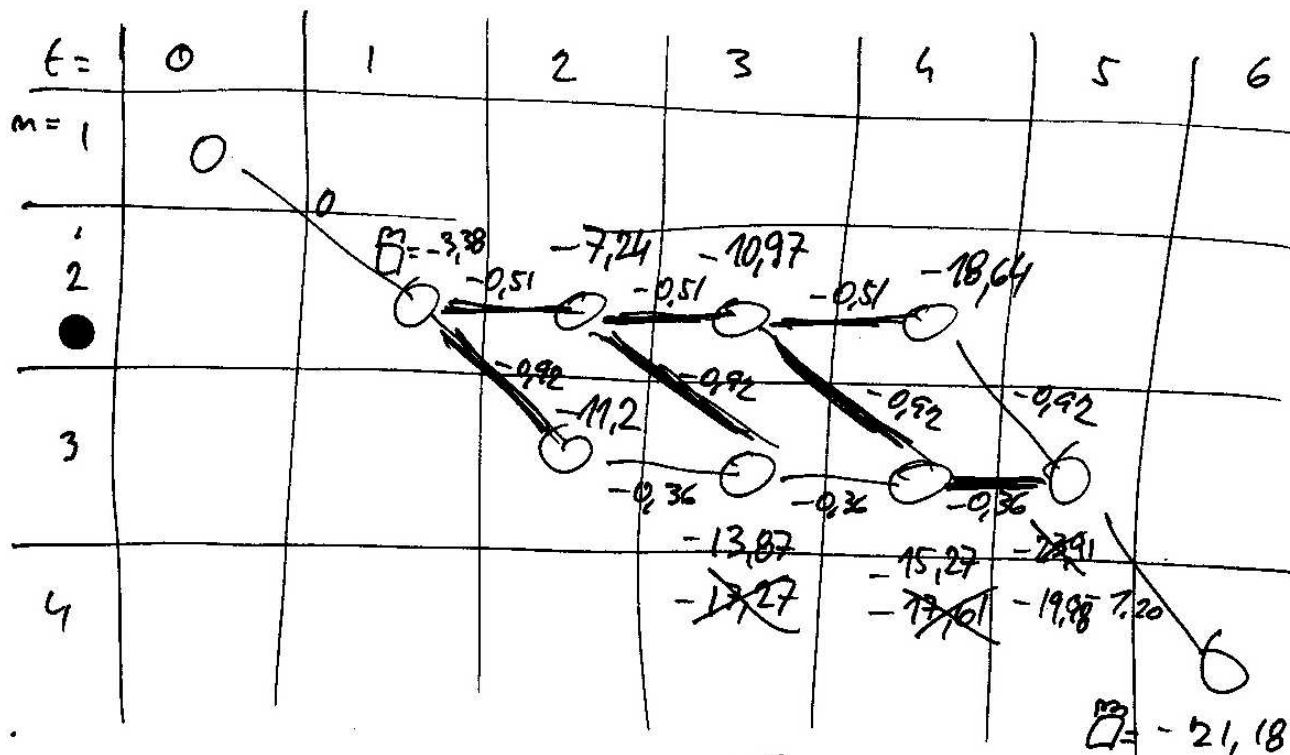
Budeme postupovat přesně podle algoritmu na konci přednášky o HMM. Je dobré si připravit obrázek, který obsahuje na svislé ose stavy modelu a na vodorovné ose časy. Časy můžeme doplnit o dva “fiktivní” časy: 0 a $T + 1$ (předpokládáme, že vektory \mathbf{O} jsou indexovány od 1 do T), ve kterých budeme algoritmus inicializovat a uzavírat. Uvědomíme si, že do piv budeme dolévat logaritmičké⁴ pravděpodobnosti $\log a_{ij} + \log b_j[\mathbf{o}(t)]$, takže bude dobré si připravit:

- do obrázku logaritmy přechodových pravděpodobností:
 $\log 1 = 0$, $\log 0.6 = -0.51$, $\log 0.4 = -0.92$, $\log 0.7 = -0.36$, $\log 0.3 = -1.20$
- tabulku logaritmů $b_j(\mathbf{o}(t))$ pro všechny vektory:

	$\mathbf{o}(1)$	$\mathbf{o}(2)$	$\mathbf{o}(3)$	$\mathbf{o}(4)$	$\mathbf{o}(5)$
$\log b_2$	-3.38	-3.35	-3.22	-6.65	-9.21
$\log b_3$	-4.63	-6.91	-5.71	-3.38	-4.35

⁴Je celkem jedno, jaký použijeme logaritmus, doporučuji přirozený – na kalkulačce \ln , v programovacích jazycích \log .

Průběh algoritmu je pak naznačen na následujícím obrázku⁵:



Po jeho doběhnutí odebereme z posledního stavu modelu pivo, a pro získání Viterbiho pravděpodobnosti odlogaritmujeme:

$$P^*(O|M) = e^{-21,18} = 6,33 \times 10^{-10}$$

což je (až na zaokrouhlovací chyby) výsledek, který jsme dostali v příkladu 4. plným procházením všech cest.

⁵Černá tečka pod číslem stavu 2 nemá žádný význam — v papíru byla díra :-)